

文章编号: 1001-0920(2011)04-0615-04

基于 Pareto 解集关联与预测的动态多目标进化算法

彭星光^a, 徐德民^{a,b}, 高晓光^c

(西北工业大学 a. 航海学院, b. 水下信息处理与控制国家级重点实验室, c. 电子信息学院, 西安 710072)

摘要: 针对动态多目标优化问题, 提出一种基于 Pareto 解集关联与预测的动态多目标进化算法(LP-DMOEA), 设计了基于超块的 Pareto 解集关联方法. 该方法能够动态维护若干描述 Pareto 解变化规律的时间序列, 通过对新环境下的 Pareto 解集进行预测来生成初始种群. 将 LP-DMOEA 应用于非劣分类遗传算法(NSGA2), 并对 3 类标准测试函数进行了实验, 所得结果表明该方法能够有效求解动态优化问题.

关键词: 动态多目标优化问题; 动态多目标进化算法; Pareto 解集关联与预测; 超块

中图分类号: TP18

文献标识码: A

A dynamic multi-objective evolutionary algorithm based on Pareto set linkage and prediction

PENG Xing-guang^a, XU De-min^{a,b}, GAO Xiao-guang^c

(a. School of Marine Engineering, b. National Key Laboratory for Underwater Information Processing and Control, c. School of Electronics and Information, Northwestern Polytechnical University, Xi'an 710072, China. Correspondent: PENG Xing-guang, E-mail: pxg0510@gmail.com)

Abstract: In order to solve dynamic multi-objective optimization problem(DMOPs), a dynamic multi-objective evolutionary algorithm based on Pareto set linkage and prediction(LP-DMOEA) is proposed and a Pareto set linking method based on hyperbox is designed. In this scheme, several time sequences which present the trend of Pareto solutions can be dynamically maintained. Based on the prediction of these time sequences, the initial population is generated. The LP-DMOEA is applied to the NSGA2 algorithm to solve three benchmark problems. Computational results show the effectiveness of the LP-DMOEA to solve DMOPs.

Key words: dynamic multi-objective optimal problem; dynamic multi-objective evolutionary algorithm; Pareto set linkage and prediction; hyperbox

1 引言

现实世界中的许多优化问题都具有多个优化目标, 并且这些优化目标和约束条件往往与时间相关. 虽然许多研究工作中, 进化算法在求解多目标优化问题时取得了很好的效果, 但如何用其求解动态多目标优化问题(DMOPs)仍是进化计算领域中有待深入研究的课题.

Jin 和 Ferina 等人^[1-2]提出了构建 DOMP 的策略和方法, 为算法比较和验证提供了若干标准测试函数. Deb^[3]将非劣分类遗传算法(NSGA2)进行了修改, 得到两种适用于不同环境变化程度的动态多目标进化

算法. 尚华荣和焦李成等人^[4]提出了求解动态优化问题的免疫克隆算法, 通过特殊算子保持所得解的多样性、均匀性和收敛性. 刘淳安等人^[5]则通过对时间区间的划分, 将任意 DMOP 转化为一个双目标静态优化问题进行求解.

对于进化算法而言, 其种群多样性关系到算法的搜索能力. 若种群多样性过快丧失, 则会导致早熟等现象. 对于动态优化问题而言, 算法多样性的维持则显得更为重要, 是算法能否进行持续寻优的关键. 多目标进化算法本身具备一定的种群多样性保持能力, 因此在动态优化情形下, 更应关注如何使其种群能够快速找到 Pareto 前沿. 为此, 本文提出一种基于 Pareto

收稿日期: 2010-01-13; 修回日期: 2010-03-23.

基金项目: 国家自然科学基金项目(60875071, 60774064); 水下信息处理与控制国家级重点实验室基金项目(9140C230503090C23).

作者简介: 彭星光(1981—), 男, 博士后, 从事进化算法及智能控制的研究; 徐德民(1937—), 男, 中国工程院院士, 教授, 博士生导师, 从事智能控制及飞行器总体设计等研究.

解集预测的动态多目标进化算法 (LP-DMOEA), 根据所获得的历史 Pareto 解来预测新环境下 Pareto 解的位置, 以此对进化过程中所产生的历史信息加以利用, 提高动态优化性能。

2 LP-DMOEA

LP-DMOEA 的核心思想是: 利用动态优化过程中所产生的历史 Pareto 解集, 以某种预测方法生成新环境下的初始种群, 即

$$\tilde{S}_p(t+1) = F_{\text{pred}}(S_p(t), \dots, S_p(t-K+1)). \quad (1)$$

其中: F_{pred} 为预测方法; $K = 1, 2, \dots, t-1$ 为预测方法的阶数; \tilde{S}_p 为预测的 Pareto 解集。

图 1 给出了 3 阶 ($K = 3$) 的 LP-DMOEA 示意图。假设在 t 时刻之后环境发生变化, 且该变化能够被准确感知, 此时算法所得到的环境变化前的 Pareto 解集为 $S_p(t)$ 。对于 $S_p(t)$ 中的每一个 Pareto 解 $P_p(t, i)$ ($i = 1, 2, \dots, |S_p(t)|$), 在 $S_p(t-1)$ 中通过一定原则可找到一个解与其相关联。由于之前 $S_p(t-1)$ 中的每个解已经与 $S_p(t-2)$ 中的解进行了关联, 此时便有了 $N_p(t)$ 条 K 阶时间序列 $\text{TS}(t, i)$ ($i = 1, 2, \dots, N_p(t)$)。每条时间序列上的点按顺序代表一段时间内一个 Pareto 解的移动趋势。然后, LP-DMOEA 将以某种方法对每条时间序列进行分析, 并预测出新环境下, 即 $t+1$ 时刻每个 Pareto 解的位置 $\tilde{S}_p(t+1, i)$ 。最后, 将新环境下的初始种群随机地产生在预测解 $\tilde{S}_p(t+1, i)$ 的周围。至此, LP-DMOEA 响应环境变化的处理机制执行完毕。之后, 继续通过交叉、变异等方法对 Pareto 解进行搜索, 直到环境再次发生改变, 重复上述过程。




图 1 LP-DMOEA 示意图 (决策空间)

可以看出, LP-DMOEA 主要包括以下两个关键步骤: Pareto 解的关联和 Pareto 解的预测与生成。

2.1 Pareto 解的关联

为了将两个 Pareto 解集中的解互相关联, 必须根据一定的参考原则。可在决策空间或目标空间中衡量各个解的相互关系并进行关联。

Zhou 等人^[6] 直接在决策空间的相邻历史 Pareto 解集中根据最小距离原则对 Pareto 解进行关联。这种方法虽然直观, 但所得到的时间序列数量与 Pareto 解

集中的非劣解数量相等, 当其数量较大时, 对时间序列进行分析和预测的计算量将会降低算法的运行效率。Hatzakis 等人^[7-8] 根据目标空间中相邻历史 Pareto 前沿上各点之间的某种关系进行关联。但 this 方法是建立在仅靠 2 ~ 3 个特征点便能刻画整个 Pareto 前沿的假设上。如果 Pareto 前沿的形状较为复杂, 则算法的结果很可能与其所期望的效果不符。另外, 该方法中的接近理想点 (CTI 点) 仅适用于 Pareto 前沿为凸的问题。

综合上述方法的优缺点, 本文在目标空间中使用超块对关联候选解进行初选, 在降低关联解数量的同时保证 Pareto 前沿的分布, 并在决策空间中动态构造若干描述历史 Pareto 前沿变化的时间序列。

2.1.1 基于超块的 Pareto 解的选取

下面以最小化问题为例详细阐述基于超块的 Pareto 解的选取过程。对于每个优化目标 f_i ($i = 1, 2, \dots, N_{\text{obj}}, N_{\text{obj}}$ 为目标空间的维数), 可以设置一个区分度参数 ε_i , 该参数将整个目标空间分为若干个超块。规定每个超块中只能存在一个 Pareto 解, 若同一超块中同时存在多个 Pareto 解, 则只保留距超块顶端点最近的解。如图 2 所示, P_1 点和 P_2 点同处于一个超块中, 因 P_2 距超块顶点更近, 故 P_2 被选中而 P_1 被删除。同理, 图中灰色的圆点代表被删除的 Pareto 解。




图 2 基于超块的 Pareto 解选取示意图 (双最小化问题)

2.1.2 时间序列的动态构造

在对 $S_p(t)$ 进行基于超块的 Pareto 解选取之后, 得到其子集 $S_p^*(t)$ 。本文采用距离最小原则, 将 $S_p^*(t)$ 中的解与 $S_p^*(t-1)$ 中的解进行关联, 即将两个解集中欧氏距离最近的两个解视为某一 Pareto 解在不同时刻的运动点。则有如下关系:

$$x(t) = \operatorname{argmin} \|x(t) - x(t-1)\|,$$

$$x(t) \in S_p^*(t), x(t-1) \in S_p^*(t-1). \quad (2)$$

LP-DMOEA 动态维护了一系列 $K > 0$ 阶时间序列, 而无需对之前的 Pareto 解集进行单独存储。每次均以 $S_p^*(t)$ 中的解为参照, 在时间序列最后一点的集合即 $S_p^*(t-1)$ 中寻找最近的解与之关联。因此, t 时刻得到的时间序列的数量为该时刻 $S_p^*(t)$ 中的解的

数量, 即 $|S_p^*(t)|$. 因为 $|S_p^*(t)|$ 可能会随着时间而变化, 所以每条时间序列的生命期是不确定的, 并且依赖于新时刻 $S_p^*(t)$ 中是否有解与其最后一个点进行关联. 若有则保留, 否则删除. 同时, 通过调节 K 的大小可以控制每条时间序列中点的个数, 以适应不同阶数的预测算法. $S_p^*(t)$ 的维护根据先进先出原则进行.

2.2 Pareto 解的预测与生成

预测方法的使用主要考虑以下3点: 1) 预测方法的变量属性(离散、连续性)必须与所施用的多目标进化算法相同; 2) 预测方法应能有效地对时间序列进行分析和预测; 3) 预测方法的计算复杂度不能太高, 否则会大大影响动态多目标进化算法的实时性. 为便于验证 Pareto 解集关联与预测方法的有效性, 本文使用线性预测模型

$$x_i(t+1) = x_i(t) + (x_i(t) - x_i(t-1)). \quad (3)$$

其中 x_t 和 x_{t-1} 为时间序列上两个邻近的时间点.

综上, LP-DMOEA 的算法流程如图3所示.

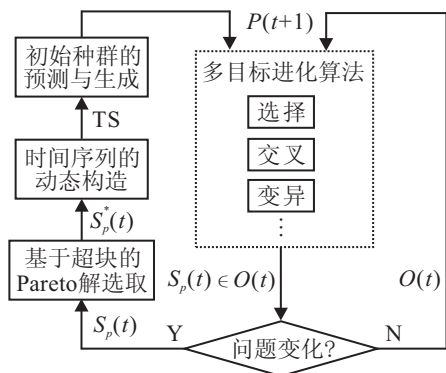


图3 LP-DMOEA 算法流程

3 实验及分析

为了对所提出的 LP-DMOEA 进行实验分析, 本文对 Farina 和 Deb 等人^[2]提出的3个标准测试函数: FDA1, FDA2 以及 FDA3 进行实验. 这里对每个算例

独立地计算 N_E 次, 通过给出性能的平均值来对算法进行度量, 即

$$E_f(t) = \frac{1}{N_E} \sum_{i=1}^{N_E} e_f^i(t). \quad (4)$$

其中: $e_f(t)$ 为目标空间中的收敛性度量^[2], 当采样点均匀且数量较大时还能度量多样性^[9]; $t = 1/n_t$ [τ/τ_t], τ 为进化代数, n_t 为问题变化的幅度, τ_t 为变化频度(即相邻两次变化间的进化代数).

另外, 本文还使用如下离线度量:

$$\bar{E}_f = \frac{1}{T} \sum_{i=1}^T \frac{1}{N_E} \sum_{j=1}^{N_E} e_f(i/n_t), \quad (5)$$

其中 T 为环境变化的次数.

实验参数为: 种群规模 $N_{pop} = 100$, 真值交叉和变异方法分别为模拟二进制交叉 (SBX) 法和多项式变异 (PM), 交叉概率 $P_{SBX} = 0.9$, 变异概率 $P_m = 1/N_{var}$, SBX 和 PM 的参数分布为 10 和 20, 实验次数 $N_E = 50$. FDA1~FDA3 每隔 20 代发生变化, 即 $\tau_t = 20, n_t = 5$.

在实验中, 将 LP-DMOEA 用于著名的 NSGA2^[10] 上, 并称相应的算法为 LP-DNSGA2. 为了进行比较分析, 同样对重启式 NSGA2(每次环境变化后随机生成初始种群, 称为 R-DNSGA2) 进行了测试.

经分析得到 FDA1~FDA3 的全局 Pareto 解集和对应的 Pareto 前沿, 如表1所示. 可以看出, FDA1 的 Pareto 解集随时间变化, 但其 Pareto 前沿不变; FDA2 的 Pareto 前沿随时间变化, 但其 Pareto 解集不变; FDA3 的 Pareto 解集和前沿均随时间而变化.

图4给出了50次独立实验后两种算法的 E_f 随 t 变化的曲线, 表2给出了二者相应的 \bar{E}_f 性能对比. 从中可以看出, 对于 FDA1~FDA3, LP-DNSGA2 比 R-DNSGA2 具有更好的收敛性和多样性.

表1 FDA1~FDA3 的全局 Pareto 解集和相应 Pareto 前沿

测试函数	Pareto 解集	Pareto 前沿
FDA1	$\{x_i(t) = G(t), x_i(t) \in \mathbf{x}_{II}\}$	$f_2 = 1 - \sqrt{f_1}$
FDA2	$\{x_1 \in [0, 1], x_i(t) = 0, x_j(t) = -1, x_i(t) \in \mathbf{x}_{II}, x_j(t) \in \mathbf{x}_{III}\}$	$f_2 = 1 - f_1^{(H(t)+15(1+H(t))^2)^{-1}}$
FDA3	$\{x_1 \in [0, 1], x_i(t) = G(t), x_i(t) \in \mathbf{x}_{II}\}$	$f_2 = (1 + G(t)) \times (1 - \sqrt{\frac{f_1}{1+G(t)}})$




图4 LP-DNSGA2 与 R-DNSGA2 的 E_f 值对比

表2 LP-DNSGA2与R-DNSGA2的 \bar{E}_f 性能对比

算法	测试函数		
	FDA1	FDA2	FDA3
LP-DNSGA2	0.021 6	0.017 0	0.146 4
R-DNSGA2	0.028 2	0.094 2	0.759 3

4 结 论

本文提出了基于 Pareto 解集预测的动态多目标进化算法, 设计了 Pareto 解的关联方法、预测方法以及预测解的生成方法. 将该算法应用于 NSGA2 算法上, 并针对 FDA1~FDA3 标准测试问题进行了测试. 实验和分析结果表明, LP-DMOEA 的优化性能优于重启策略, Pareto 解集关联与预测方法能够有效地求解动态多目标优化问题.

为了便于验证 Pareto 解集关联与预测方法的有效性, 本文使用了线性预测方法. 在今后的工作中, 可进一步研究历史进化信息的分析和预测方法, 综合考虑 Pareto 解集在决策空间中的变化方式以及 Pareto 解时间序列的构建方式, 设计和使用更为准确和合理的预测方法.

参考文献(References)

- [1] Jin Y, Sendhoff B. Constructing dynamic test problems using the multi-objective optimization concept[C]. Proc of the 2004 Evolutionary Workshops. Berlin: Springer-Verlag, 2004: 525-536.
- [2] Farina M, Deb K, Amato P. Dynamic multiobjective optimization problems: Test cases, approximations, and applications [J]. IEEE Trans on Evolutionary Computation, 2004, 8(5): 425-442.
- [3] Deb K, Udaya Bhaskara Rao N, Karthik S. Dynamic multi-objective optimization and decision-making using modified NSGA-II: A case study on hydro-thermal power scheduling[R]. Kanpur: India KanGAL, Indian Institute Technology of Kanpur, 2006.
- [4] 尚荣华, 焦李成, 公茂果, 等. 免疫克隆算法求解动态多目标优化问题[J]. 软件学报, 2007, 18(11): 2700-2711. (Shang R H, Jiao L C, Gong M G, et al. An immune clonal algorithm for dynamic multi-objective optimization[J]. J of Software, 2007, 18(11): 2700-2711.)
- [5] 刘淳安, 王宇平. 基于新模型的动态多目标优化进化算法[J]. 计算机研究与发展, 2008, 45(4): 603-611. (Liu C A, Wang Y P. Dynamic multi-objective optimization evolutionary algorithm based on new model[J]. J of Computer Research and Development, 2008, 45(4): 603-611.)
- [6] Zhou A, Jin Y, Zhang Q, et al. Prediction-based re-initialization for evolutionary dynamic multi-objective optimization[C]. Proc of the 4th Int Conf on Evolutionary Multi-criterion Optimization. Berlin: Springer-Verlag, 2007: 832-846.
- [7] Hatzakis I, Wallace D. Dynamic multi-objective optimization with evolutionary algorithms: A forward-looking approach[C]. Proc of the 8th Annual Conf on Genetic and Evolutionary Computation. New York: ACM, 2006: 1201-1208.
- [8] Hatzakis I, Wallace D. Topology of anticipatory populations for evolutionary dynamic multi-objective optimization[C]. 11th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conf. Portsmouth: AIAA, 2006.
- [9] Zhang Q, Zhou A, Jin Y. RM-MEDA: A regularity model-based multiobjective estimation of distribution Algorithm[J]. IEEE Trans on Evolutionary Computation, 2008, 12(1): 41-63.
- [10] Deb K. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Trans on Evolutionary Computation, 2002, 6(2): 182-197.

(上接第614页)

- [15] 金尚泰, 侯忠生. 一类非线性大滞后系统的改进无模型自适应控制[J]. 控制理论与应用, 2008, 25(4): 623-627. (Jin S T, Hou Z S. An improved model-free adaptive control for a class of nonlinear large-lag systems[J]. Control Theory & Applications, 2008, 25(4): 623-627.)
- [16] Leandro dos Santos Coelho, Antonio Augusto Rodrigues Coelho. Model-free adaptive control optimization using a chaotic particle swarm approach[J]. Chaos, Solitons and Fractals, 2009, 41(4): 2001-2009.
- [17] Astrom K J. Adaptive feedback control[J]. Proc of the IEEE, 1987, 75(2): 185-217.
- [18] Ramasamy M, Sundaramoorthy S. PID controller tuning for desired closed-loop responses for SISO systems using impulse response[J]. Computers and Chemical Engineering, 2008, 32(8): 1773-1788.
- [19] Jeng J C, Huang H P, Lin F Y. Modified relay feedback approach for controller tuning based on assessment of gain and phase margins[J]. Industrial and Engineering Chemistry Research, 2006, 45(12): 4043-4051.